

基于小波分解和模糊聚类的模拟电路软故障诊断

刘美容^{1,2}, 张立玮¹

(1 湖南师范大学 物理与信息科学学院, 湖南 长沙 410082;

2 合肥工业大学 电气工程博士后流动站, 安徽 合肥 230009)

摘 要: 为了解决模拟电路故障诊断中出现的故障特征冗余的问题, 提出一种采用小波分解和模糊聚类提取故障特征的模拟电路故障诊断方法. 对被测电路的输出进行小波分解, 将得到的重构小波系数作为故障特征而构成测试矩阵, 再利用基于马氏距离的模糊聚类的方法对测试矩阵进行划分, 降低测试矩阵的维数, 最后用 BP 神经网络进行故障诊断. 仿真实验结果表明, 所提出的方法能有效提取出故障特征, 并且具有较高的模拟电路故障诊断准确率.

关键词: 模拟电路; 故障诊断; 小波分解; 模糊聚类

中图分类号: TP206+.3

文献标识码: A

文章编号: 1000-7180(2014)12-0140-04

Analog Circuit Soft Fault Diagnosis Based on Wavelet Analysis and Fuzzy Clustering

LIU Mei-rong^{1,2}, ZHANG Li-wei¹

(1 College of Physics and Information Science, Hunan Normal University, Changsha 410082, China;

2 Electric Engineering Postdoctoral Center, Hefei University of Technology, Hefei 230009, China)

Abstract: A method of analog circuit fault diagnosis based on extracting fault features by using wavelet decomposition and fuzzy clustering is presented in this paper. This approach performs wavelet decomposition on the acquired output signals of the test circuit and takes the reconstructing wavelet coefficients as the fault feature values, then using the method of fuzzy clustering based on markov distance to division the test matrix to reduce the dimensions of the test matrix, finally the obtained test matrix are inputted into the neural network for fault diagnosis. The simulation result show 是 that the proposed method can effectively extract the fault feature and obtain well accuracy of analog circuit fault diagnosis.

Key words: analog circuit; fault diagnosis; wavelet decomposition; fuzzy clustering

1 引言

模拟电路故障诊断是网络理论的第三大分支, 一直是现代电路理论研究的热点和难点^[1]. 许多学者提出了各种应用于模拟电路故障诊断的方法, 但是模拟电路由于其非线性、元件的容差性、故障的多样性使其在故障诊断方面比数字电路故障诊断复杂得多. 近些年, 基于神经网络、小波分析等方法在模拟电路故障诊断领域得到了广泛的应用^[2], 取得了

很好的效果; 在故障诊断中, 故障模式的数学表达式一般是用特征值来表示的, 故障特征值的好坏直接影响到分类器的性能^[3]. 本文提出一种小波分解与模糊聚类相结合的故障特征提取方法来进行故障诊断.

2 小波分解方法

小波是一种常用的信号处理方法, 广泛应用于信号处理领域中. 它可将信号分解成为能反映信号

收稿日期: 2014-01-30; 修回日期: 2014-03-25

基金项目: 国家自然科学基金项目(60876022); 湖南省科技计划项目(2012FJ4347)

本质信息的逼近部分和细节部分,以便于进一步分析处理^[4].小波变换将信号分解在这样一组函数上,它们是在能量有限信号的函数空间上的稠密正交基,并且单由一个函数的伸缩和平移生成,这样的函数为母小波,由它生成的一组正交基成为小波函数^[5].

定义:如果 $\psi(t) \in L^2(R)$ 满足允许条件,则

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega \quad (1)$$

式中, $\hat{\psi}(\omega)$ 为傅里叶变换,那么 $\psi(t)$ 叫做可允许小波.

由小波生成的小波函数系为

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

将信号在这个函数系上做分解,就得到了连续变换的定义.

对可允许小波函数 $\psi_{a,b}(t)$ 连续小波变换为

$$(W_\psi f)(a,b) = \int_{-\infty}^{\infty} f(t) \bar{\psi}_{a,b}(t) dt \quad (3)$$

对上式中 a, b 做离散化,就可以得到离散小波分析,离散小波函数:

$$\psi_{j,k}(t) = a_0^{-\frac{j}{2}} \psi(a_0^{-j}t - kb_0) \quad (4)$$

离散小波变换系数为

$$(W_{j,k})(t) = \int_{-\infty}^{\infty} f(t) \bar{\psi}_{j,k}(t) dt \quad (5)$$

小波重构公式:

$$f(t) = c \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} W_{j,k} \psi_{j,k}(t) \quad (6)$$

式中, c 为与信号无关的参数.

小波分析相对于对于其他时频分析方法的优势在于它可以在任意时频分辨率上将信号分解,相当于一个信号分别通过低通和高通滤波器,多分辨率分析只是对低频部分进一步分解,高频部分不予考虑,以下再分解依此类推,如图1所示, S 是原信号, A 是信号的低频部分, D 是信号的高频部分,分解具有关系 $S=A_2+D_2+D_1$ ^[6].




图1 小波分解方法

3 模糊聚类分析

模糊聚类是统计学中一种多元分析方法,用数学方法定量的确定样本的亲疏关系,客观地划分类型.由于模糊等价关系, R 是论域集 U 与自己的直积 $U \times U$ 上的一个模糊子集,因此可以对 R 进行分解,当用 λ 水平对 R 作截集时,截得 $U \times U$ 的普通子集 R_λ 就是 U 上的一个普通等价关系,也就得到了关于 U 中被分类元素的一种分类.

设论域 $\{x_1, x_2, \dots, x_n\}$ 为被分类对象,每个对象又有 m 个指标表示其性状, $x_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$, 得到原始数据矩阵:

$$m = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (7)$$

式中, x_{nm} 表示第 n 个分类对象的第 m 个指标.首先对采集到的数据进行标准化处理,压缩至区间 $[0, 1]$ 中,然后依照传统聚类方法确定相似系数 r_{ij} , 建立模糊相似矩阵 $R = (r_{ij})_{m \times n}$; 确定 r_{ij} 的方法主要有相关系数法、距离法等^[7].

相关系数法:

$$r_{ij} = \frac{\sum_{k=1}^m |x_{ik} - \bar{x}_i| |x_{jk} - \bar{x}_j|}{\sqrt{\sum_{k=1}^m (x_{ik} - \bar{x}_i)^2} \sqrt{\sum_{k=1}^m (x_{jk} - \bar{x}_j)^2}} \quad (8)$$

其中, $\bar{x}_i = \frac{1}{m} \sum_{k=1}^m x_{ik}$, $\bar{x}_j = \frac{1}{m} \sum_{k=1}^m x_{jk}$.

距离法:

$$r_{ij} = 1 - cd(x_i, x_j) \quad (9)$$

式中, c 为适当选取的参数,使得 $0 < r_{ij} < 1$, d 表示它们之间的距离.本文采用距离法求相似系数 r_{ij} , 因为马氏距离是通过计算数据样本间的协方差距离来度量两个样本间的相似度,马氏距离越小,表明两个样本间的相似度越大,并且马氏距离不受量纲的影响,独立于测量尺度,能够考虑到各个特征之间的联系,可以排除变量之间相关的干扰,比传统的欧氏距离有更大的优势^[8], 所以本文选用马氏距离构建模糊矩阵. 对于一个协方差矩阵为 D 的多变向量 $x = (x_1, x_2, \dots, x_n)^T$, 马氏距离为

$$M_D = \sqrt{(x_i - x_j)^T D^{-1} (x_i - x_j)} \quad (10)$$

如果协方差为单位矩阵,则其转化为欧氏距离. 通常的模糊关系,不一定有传递性,因而不是模糊等价关系,对这种模糊关系直接进行分类是不合理的,

还要将其改造成模糊等价矩阵 R^* 才能进行分类使用. 因为 R 的传递闭包 $t(R)$ 是 R 的最小传递关系, 所以可以根据 R 的传递闭包 $t(R) = R^*$ 求得 R^* . R^* 是 A 上的模糊等价关系.

$$R^* = \begin{bmatrix} a_{11}^\lambda & \cdots & \cdots \\ \cdots & \cdots & \cdots \\ a_{n1}^\lambda & \cdots & a_{ij}^\lambda \end{bmatrix} \quad (11)$$

则其 λ 截关系是经典等价关系, 它们都可以将 x 作一个划分, 当 λ 从 1 下降到 0 时, 就得到一个划分族, $a_{ij} \geq \lambda$ 时, $a_{ij}^\lambda = 1$, $a_{ij} < \lambda$ 时, $a_{ij}^\lambda = 0$, 随着 λ 的下降, R^* 的分类越来越粗, 对于不同的 λ , 可以得到不同的分类结果, 形成一个动态的聚类图; 根据实际需要, 在动态聚类图中调整 λ 得到适当的截矩阵 R_λ , 得到分类 $\{x_{i1} \cdots\}, \cdots, \{x_{mi} \cdots\}$. 如果几个数据处于一个分类中, 则说明它们相似性较高, 可以合并为一个, 使用这种方法可以在庞大的特征向量中选择适当数据, 而不会太多的减少故障信息.

4 仿真实例与分析

4.1 诊断流程

本文提出的故障诊断流程如图 2 所示.




图 2 诊断流程

故障诊断具体步骤如下:

首先给诊断电路施加一个电压信号, 在输出端采集到测试信号; 然后将测试信号进行小波分解, 将小波重构系数作为特征向量提取出来, 作为故障信息; 接下来用模糊聚类的方法对特征向量进行降维处理; 将处理后的数据作为神经网络的输入, 对神经网络进行训练; 最后使用训练好的神经网络进行故障识别.

4.2 故障模式设置

考虑典型诊断电路图 3 所示 sally-key 带通滤波电路为例介绍本文的模拟电路故障诊断方法.

电路中元件的大小如图 3 所示, 其中电阻、电容的容差为 5%. 因为 R_2, R_3, C_1, C_2 对电路影响较大, 所以只考虑这几个元件上的软故障.

故障情形: 当电路中的元件高于或低于正常值




图 3 sally-key 带通滤波器

的 50%, 而其他元件在它们的容差范围内变化时, 对电路仿真获得的故障冲击响应. $\uparrow$ 表示偏离元件标称值 +50%, $\downarrow$ 表示偏离元件标称值 -50%, 加上正常状态一共得到 9 个故障类别, 如表 1 所示.

表 1 故障模式

故障编号	故障类别	故障编号	故障类别
F0	正常	F5	$R_2 \uparrow$
F1	$C_1 \uparrow$	F6	$R_2 \downarrow$
F2	$C_1 \downarrow$	F7	$R_4 \uparrow$
F3	$C_2 \uparrow$	F8	$R_4 \downarrow$
F4	$C_2 \downarrow$		

4.3 故障特征提取

采用表 1 中设置的故障对电路进行仿真. 对电路输入 1 V 的交流电源, 并进行 50 次蒙特卡洛交流扫描分析, 同时在电路的输出端 V_{out} 对输出信号进行采样, 获取 200 个采样点. 然后对采集到的数据小波分解, 太高层次的分解容易丢失原来信号信息, 所以对信号进行 5 层 haar 小波分解, 提取重构小波的系数, 得到故障样本数据, 如表 2 所示.

根据本文提出的方法, 对故障样本数据进行归一化处理, 并采用模糊聚类的方法提取出能有效表示整个信号的特征向量. 减少了神经网络的输入, 再对每个故障进行编号, 然后再作为输入对 BP 神经网络进行训练. 经过处理后的数据如表 3 所示. 取任意一组测试向量, 对训练好的神经网络进行测试, 如表 4 所示. 对得到测试结果进行分析, 几乎全部测出故障状态, 如表 5 所示.

表 2 故障样本

	1	2	3	...	34
F0	0.000 5	0.000 5	0.000 7	...	2.966 9
F1	0.000 5	0.000 5	0.000 6	...	2.978 5
F2	0.000 6	0.000 6	0.000 7	...	2.958 5
F3	0.000 6	0.000 6	0.000 7	...	2.984 3
F4	0.000 5	0.000 5	0.000 6	...	2.943 3
F5	0.000 6	0.000 5	0.000 7	...	2.968 3
F6	0.000 5	0.000 5	0.000 7	...	2.965 1
F7	0.000 5	0.000 5	0.000 7	...	2.644 2
F8	0.000 5	0.000 5	0.000 7	...	3.391 5

表 3 化简后的故障特征

	4	18	20	24	25	27	29	32	34	故障编号
F0	0.000 1	0.025 6	0.053 6	0.231 3	0.329 6	0.630 9	0.959 4	0.745 5	0.440 5	0000
F1	0.000 1	0.029 4	0.061 5	0.263 8	0.373 2	0.687 1	0.975 6	0.765 2	0.466 1	0001
F2	0.000 0	0.017 6	0.036 8	0.160 5	0.231 7	0.478 4	0.890 7	0.682 3	0.368 4	0010
F3	0.000 1	0.022 4	0.046 9	0.202 8	0.289 7	0.562 8	0.905 9	0.855 7	0.546	0011
F4	0.000 1	0.029 3	0.061 4	0.264	0.375 1	0.703 2	1.000 0	0.673 5	0.383 9	0100
F5	0.000 1	0.034 2	0.071 5	0.304 6	0.428 1	0.760 7	1.000 0	0.684 4	0.399 8	0101
F6	0.000 0	0.016 8	0.035 2	0.153	0.220 1	0.445 2	0.807 0	0.889 5	0.560 7	0111
F7	0.000 1	0.028 4	0.059 4	0.256 1	0.364 5	0.690 4	1.000 0	0.672 8	0.381 5	1000
F8	0.000 1	0.023 2	0.048 5	0.209 3	0.298 7	0.575 8	0.911 7	0.859 4	0.554 6	1010

表 4 测试向量

	4	18	20	24	25	27	29	32	34	期望输出
F0	0.000 1	0.025 5	0.053 3	0.230 0	0.327 8	0.628 4	0.958 4	0.745 1	0.439 9	0000
F1	0.000 1	0.026 7	0.055 9	0.240 7	0.342 3	0.647 9	0.964 5	0.752 2	0.448 8	0001
F2	0.000 1	0.023 9	0.050 0	0.216 5	0.309 6	0.602 6	0.949 6	0.735 5	0.428	0010
F3	0.000 1	0.030 2	0.063 1	0.271 3	0.384 9	0.717 1	1.000 0	0.649 9	0.367 6	0011
F4	0.000 1	0.020 8	0.043 6	0.188 5	0.269 6	0.526 8	0.868	0.910 6	0.617 0	0100
F5	0.000 1	0.026 3	0.055 1	0.237 6	0.338 4	0.644 4	0.966 9	0.738 2	0.435 0	0101
F6	0.000 1	0.024 6	0.051 4	0.222 1	0.316 9	0.611 6	0.949	0.753 3	0.445 8	0111
F7	0.000 1	0.024 1	0.050 5	0.218 1	0.311 1	0.598 6	0.933 3	0.796 8	0.487 9	1000
F8	0.000 1	0.027 0	0.056 5	0.243 9	0.347 5	0.662 7	0.985 1	0.703 5	0.404 7	1010

表 5 测试数据识别结果

测试输出				期望输出
0.066	0.015 9	0.099 8	0.184 9	0000
0.041 6	0.018 1	0.258	1.024 7	0001
0.022 8	0.046 8	1.151 7	0.021 9	0010
0.002 2	0.014 3	0.821 4	0.958 3	0011
0.053 9	0.979 9	0.003 6	0.006 4	0100
0.047 8	0.633 6	0.282 9	0.760 1	0101
0.037 7	0.844 9	0.677 2	0.795 1	0111
1.013 0	0.014	0.353 5	0.043 6	1000
1.066 5	0.017 7	0.618 4	0.110 2	1010

5 结束语

本文提出的将小波分解与模糊聚类相结合提取故障特征的模拟电路故障诊断方法,先通过小波分解有效的提取电路故障特征,再利用模糊聚类的方法简化故障特征维数,减少了神经网络的输入,利用样本训练神经网络,最后用训练好的神经网络对故障进行模式分类.运用本文所提出的方法结合 sally-key 带通滤波器进行建模、仿真,诊断结果精确度高,证明该方法有效的提取出了故障特征,在模拟电路故障诊断上确实有效.

参考文献:

[1] 杨士元. 模拟系统的故障诊断与可靠性设计[M]. 北京:清华大学出版社,1993.

[2] 廖薇,许春冬,刘锦高. 基于神经网络的模拟电路故障诊断研究[J]. 微电子学与计算机, 2010, 27(5): 126-128.

[3] 王天扬,程卫东,李建勇. 基于 3 种测度值的特征提取方法优化评价[J]. 仪器仪表学报, 2010, 31(4): 898-903.

[4] 肖迎群,何怡刚. 基于小波分形分析和脊波网络的模拟电路故障诊断方法[J]. 电工技术学报, 2011, 26(11): 105-114.

[5] 浦建开. 基于小波分析和马氏距离的模拟电路故障诊断[D]. 南京:南京航空航天大学,2011.

[6] 胡昌华,张军波,夏军,等. 基于 MATLAB 的系统分析和设计-小波分析[M]. 西安:西安电子科技大学出版社,2000.

[7] 曲福横,崔广才,李岩芳,等. 模糊聚类算法及应用[M]. 北京:国防工业出版社,2011.

[8] 陈志奎,吕爱玲,张清辰. 基于属性重要性的不完备数据填充算法[J]. 微电子学与计算机, 2013, 30(7): 167-176.

作者简介:

刘美容 女,(1977-),博士,讲师. 研究方向为信号处理、神经网络、故障诊断.

张立玮 男,(1988-),硕士. 研究方向为故障诊断、信号处理. E-mail:zhangliwei924@163.com.